



Evaluation of Chemistry Questions in Universities and Higher Education Institutes Entrance Exam 2017 Using Item Response Theory

Alireza Karami-Gazafi¹, Sara Mehrabi², Farzad Zandi³

1. Assistant Professor, Faculty of Basic Sciences, Shahid Rajaee Teacher Training University, Tehran, Iran; (Corresponding Author), Email: ar.karami@sru.ac.ir

2. Department of Chemistry, Faculty of Basic Sciences, Shahid Rajaee Teacher Training University, Tehran, Iran. Email: sara.mehrabi.chemeducation@gmail.com

3. Associate Professor, Department of Educational Psychology, Islamic Azad University, Sanandaj Branch, Sanandaj, Iran. Email: farzadzandi547@yahoo.com

Article Info

ABSTRACT**Article Type:****Research Article**

Received:

2019.04.06

Revised:

2019.08.01

Accepted:

2019.08.07

Published online:

2019.08.08

Objective: The aim of this study is to evaluate the chemistry questions of universities and higher education institutes entrance exam in 2017 by using item-response theory.**Methods:** This is an applied and descriptive research. Participants' 5,000 answer sheets in Empirical Science group were selected randomly as sample. All parameters were calculated with NOHARM and IRTPRO and EXCEL softwares.**Results:** First, the initial assumptions of IRT theory (unidimensionality and local independence) were investigated. The parameters of each questions, such as difficulty and discrimination coefficient, were calculated based on the classic and the item response theories. The results showed that 7 questions show a good fit with one and two-parameter models and 21 questions are also compatible with three-parameter model and 13 questions do not fit with any IRT models. The analysis with 3-PL-IRT showed the discrimination coefficient of 26 questions are strong ($a > 1.3$), 6 are moderate and 3 are weak ($a < 0.65$). Also 11 questions were very difficult ($b > 1.2$) and 24 questions were appropriate ($-1.2 < b < 1.2$). The guessing parameter for 16 questions, were $c \geq 0.2$, which indicates the high predictability of the test.**Conclusion:** The results showed that 3-PL IRT model has a better fit with the test. All questions are efficient in terms of discrimination coefficient and have a high level of difficulty and also guessing parameter is high in this test. The test's questions have the highest Information and the least error for a high level of ability (range -1 to 2).**Keywords:** Evaluation, University Entrance Exam, Chemistry Education, Classic Theory, Item-Response Theory.

How to Cite: Karami-Gazafi, Alireza; Mehrabi, Sara; Zandi, Farzad (2021). Evaluation of Chemistry Questions in Universities and Higher Education Institutes Entrance Exam in 2017 Using Item Response Theory. *Educational Measurement and Evaluation Studies*, 11 (34): 113-136 Pages. DOI:10.22034/EMES.2021.248201© The Author(s).
Publisher: National Organization of Educational Testing (NOET)

مطالعات اندازه‌گیری و ارزشیابی آموزشی



سازمان پژوهش و نوآوری کشور

شایا اینترنتی: ۰۹۴۲-۲۸۶۵-۲۴۷۶

شایا جابی: ۰۹۴۳-۲۷۸۳

ارزشیابی سؤال‌های شیمی کنکور سراسری رشته علوم تجربی در سال ۱۳۹۶ با استفاده از نظریه سؤال-پاسخ

علیرضا کرمی گرافی^۱ سارا مهرابی^۲ فرزاد زندی^۳

- استادیار گروه شیمی، دانشکده علوم پایه، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران؛ (نویسنده مسئول)، پست الکترونیک: ar.karami@sru.ac.ir
- گروه شیمی، دانشکده علوم پایه، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران. پست الکترونیک: sara.mehrabi.chemeducation@gmail.com
- دانشیار، گروه روان‌شناسی تربیتی، دانشگاه آزاد اسلامی، سنتندج، ایران. پست الکترونیک: farzadzandi547@yahoo.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	هدف: در پژوهش حاضر، سؤال‌های شیمی کنکور سراسری گروه علوم تجربی در سال ۱۳۹۶ با استفاده از نظریه سؤال-پاسخ ارزشیابی شده است.
دربافت: اصلاح: پذیرش: انتشار:	روش پژوهش: روش پژوهش، کاربردی، توصیفی-پیمایشی است. جامعه آماری، شامل همه داوطلبان کنکور سراسری گروه علوم تجربی در سال ۱۳۹۶ و نمونه آماری ۵۰۰۰ پاسخ‌نامه از میان پاسخ‌نامه‌های داوطلبان شرکت‌کننده در این سال است و محاسبات با نرم‌افزارهای EXCEL و NOHARM و IRTPRO انجام گرفته است.
۱۳۹۸/۰۱/۱۷ ۱۳۹۸/۰۵/۱۰ ۱۳۹۸/۰۵/۱۶ ۱۳۹۸/۰۵/۱۷	یافته‌ها: بر اساس نظریه کلاسیک و سؤال-پاسخ، پارامترهای تک تک سؤال‌ها محاسبه شد. نتایج نشان داد ۷ سؤال هم با مدل یکپارامتری و هم دوپارامتری و ۲۱ سؤال با مدل سهپارامتری برازش مناسبی نشان می‌دهند و ۱۳ سؤال نیز با هیچ‌کدام از مدل‌های نظریه سؤال-پاسخ برازش نشان نمی‌دهند. تحلیل سؤال‌ها با مدل سهپارامتری نشان داد که ۲۶ سؤال از نظر ضریب تشخیص، قوی (۱.۳) > a > b > 1.2، متوسط و ۳ سؤال، ضعیف (a < 0.65) هستند. همچنین از نظر دشواری، ۱۱ سؤال بسیار سخت (2.2 > b > 1.2) و ۲۴ سؤال مناسب (1.2 > b > 0.2) بودند. سؤال ۰.2 نسبت بینگر حدس‌پذیری بالای سؤال‌های شیمی آزمون است.
نحوه توانایی در گستره توانایی -۰/۵-۰/۰ تا ۲ بیشترین آگاهی و کمترین خطرا دارد. با توجه به فرآویانی داوطلبان در این محدوده از توانایی به نظر می‌رسد این آزمون توانایی لازم برای تشخیص داوطلبان مختلف و انتخاب عادلانه آنها برای دانشگاه‌ها را داشته باشد. آلفای کرونباخ آزمون ۰/۹۳۴ و نشان‌دهنده پایایی عالی آزمون است.	نتیجه‌گیری: این آزمون ۳۵ سؤالی، دارای ضریب دشواری ۰/۳ و عامل حدس حدود ۰/۲ است و برای سطوح توانایی در گستره توانایی -۰/۵-۰/۰ تا ۲ بیشترین آگاهی و کمترین خطرا دارد. با توجه به فرآویانی داوطلبان در این محدوده از توانایی به نظر می‌رسد این آزمون توانایی لازم برای تشخیص داوطلبان مختلف و انتخاب عادلانه آنها برای دانشگاه‌ها را داشته باشد. آلفای کرونباخ آزمون ۰/۹۳۴ و نشان‌دهنده پایایی عالی آزمون است.
وازگان کلیدی: ارزشیابی، کنکور، آموزش شیمی، کلاسیک، نظریه سؤال-پاسخ،	

استناد: کرمی گرافی، علیرضا؛ مهرابی، سارا؛ زندی، فرزاد (۱۴۰۰). ارزشیابی سؤال‌های شیمی کنکور سراسری رشته علوم تجربی در سال ۱۳۹۶ با استفاده از نظریه سؤال-پاسخ فصلنامه مطالعات اندازه‌گیری و ارزشیابی آموزشی، ۱۱(۳)، ۱۱۳-۱۳۶. DOI: 10.22034/EMES.2021.248201

ناشر: سازمان سنجش آموزش کشور حق مؤلف © نویسنده‌گان.



مقدمه

امروزه نظام آموزشی به عنوان ابزاری مهم در رشد و توسعه همه‌جانبه کشور شناخته می‌شود و ارزشیابی یکی از ملاک‌های اصلی این نظام است. ملکی (۱۳۹۲) هدف از ارزشیابی را بهبود فرایند یادگیری و رشد همه‌جانبه دانش‌آموزان می‌داند. در واقع سنجش و ارزشیابی بخش جدایی‌ناپذیر آموزش به شمار می‌رود که بدون استمرار دقیق آن، رسیدن به هدف‌های مورد نظر به صورت مطلوب، ناممکن خواهد بود (نفیسی، ۱۳۷۶). کنکور یکی از آزمون‌های مهمی است که همه‌ساله برگزار می‌شود تا داوطلبان ورود به آموزش عالی را ارزیابی و گزینش کند. در کشور ما به دلیل میزان بالای تقاضای آموزش عالی و عرضه محدود آن، آزمون سراسری دانشگاه‌ها به مهم‌ترین رخداد آموزشی (بلکه چالش آموزشی کشور) تبدیل شده است. رخدادی که در آن حجم وسیعی از نیروهای انسانی در گیر هستند و روح و روان بسیاری از افراد جامعه، هزینه و منابع بسیاری را به خود اختصاص داده است. همچنین، موجب آسیب‌های مختلف اجتماعی - فرهنگی، آموزشی، اقتصادی شده و از چالش‌های اصلی کشور مطرح شده است (محمدیان، ۱۳۹۰). از نظر اقتصادی، کنکور سراسری یکی از پرهزینه‌ترین آزمون‌هایی است که سالانه برگزار می‌شود. در سال ۱۳۹۶ هزینه ثبت نام به ازای شرکت در یک گروه آزمایشی ۲۰۰/۰۰۰ ریال بود، هزینه استفاده از خدمات پیام کوتاه: ۵/۰۰۰ ریال، هزینه اعلام علاقه‌مندی برای دانشگاه‌های پیام نور، غیر انتفاعی و فرهنگیان ۵۱/۰۰۰ ریال و هزینه شرکت در گروههای هنر و زبان هر کدام ۲۰۰/۰۰۰ ریال بود. این هزینه‌ها در حالی است که در سال ۱۳۹۶ تعداد کل داوطلبان شرکت‌کننده ۹۲۹۷۹۱ نفر بوده است و این تنها بخش کوچکی از همه هزینه‌های آشکار و پنهانی است که هر ساله در برگزاری این آزمون مهم صرف می‌شود. افزون بر آن، می‌توان شرکت در آزمون‌های آزمایشی، هزینه‌های سراسام‌اور معلمان خصوصی و رده‌های کنکور، تهیه کتاب، سی دی و انواع وسایل کمک‌آموزشی توسط داوطلبان را نیز نام برد که نشان از وجود یک صنعت پول‌ساز در پشت فرایند پذیرش دانشجو در ایران دارد. از طرفی، تاکنون راه عادلانه، نفوذناپذیر و کم‌تبغیض تری نسبت به کنکور سراسری به عنوان جایگزین آن معرفی نشده و علی‌رغم تمامی انتقادات هنوز بهترین شیوه ورود به دانشگاه، کنکور سراسری است. بنابراین، انتخاب سؤال‌های این آزمون برای داوطلبان و نیز جامعه علمی آینده کشور بسیار مهم و سرنوشت‌ساز است؛ به همین دلیل، بررسی اصول و قواعد آزمون‌سازی و پذیرش شوند و از یکسو، روان‌سنجی سؤال‌های کنکور مهم تلقی می‌شود تا افراد قوی تر و مستعدتر شناسایی و پذیرش شوند و از یکسو، عدالت در پذیرش رعایت شده باشد و از سوی دیگر با ورود افراد قوی تر، دانشگاه‌ها و بدنی کارشناسی مراکز علمی و خدماتی استخدام کننده این افراد ارتقا یابد. سازمان سنجش آموزش ایران با یک چالش بزرگ و سالانه روبروست؛ زیرا هر سال باید تعداد ۳۵ سؤال از سرفصل‌های نسبتاً ثابت، محدود و تکراری کتاب‌های درسی شیمی دبیرستان را طراحی و با برگزاری آزمون، افراد شایسته را گزینش و پذیرش کند. سؤال‌های خیلی آسان و زیاد دشوار مناسب نیستند؛ زیرا در حالت اول، همه داوطلبان آن را پاسخ خواهند داد و در حالت دوم، نمره همه داوطلبان در بخش شیمی صفر خواهد بود و بنابراین نمی‌توان بین داوطلبان هیچ تفاوتی قائل شد. میزان

پاسخگویی به سؤال‌های همراه با حدس نیز از ویژگی‌های رتبه‌بندی یک سؤال است و سختی و هنر طراحان سؤال و سازمان سنجش آموزش کشور در این مرحله مشخص می‌شود. اما مسئله جدی‌تر آن است که فرایند طراحی سؤال با ضریب تشخیص بالا، هر سال از سه کتاب شیمی با سرفصل محدود باید تکرار شود و البته این مسئله و چالش مهم، بزرگ و مرتبط با سرنوشت داوطلبان و آینده علمی کشور، برای چندین درس اختصاصی و عمومی دیگر نیز وجود دارد. این مشکلات، اهمیت و سختی کار طراحان سؤال در سازمان سنجش آموزش کشور را نمایان می‌سازد. تفسیر نمره‌های آزمون، بهبود سؤال‌های آزمون و شیوه‌های آزمودن، بازخوردهای سازنده‌ای در اختیار فراغیران، معلمان، آزمون‌سازان و سیاست‌گذاران قرار می‌دهد (عباسی و همکاران، ۱۳۹۲). این تحلیل، همچنین اطلاعات تشخیصی لازم را برای بررسی کیفیت یادگیری دانش‌آموزان و مشکلات آموزشی معلمان فراهم می‌آورد (سپاسی، ۱۳۸۲). بر این اساس، ارزشیابی سؤال‌های هر سال در کنکور سراسری یک راهنمای بسیار خوب برای طراحان سؤال برای سال‌های بعد است تا سؤال‌های مناسب و نامناسب را شناسایی کرده و از تجربه آنها در طراحی سال‌های آینده استفاده کنند؛ از این‌رو هدف از اجرای این پژوهش، ارزشیابی سؤال‌های شیمی کنکور سراسری سال ۱۳۹۶ با استفاده از نظریه جدید و توانمند سؤال‌پاسخ است تا با تحلیل دقیق و کامل آزمون، دشواری، ضریب تشخیص، عامل حدس، توانایی و میزان آگاهی سؤال‌ها و آزمون برآورده شود که درنهایت بتوان با این اطلاعات، یک بانک سؤال خوب تهیه کرد و از این سؤال‌ها یا سؤال‌های مشابه برای آزمون‌های آزمایشی، سؤال‌های امتحانات نهایی، کنکور سراسری، شناسایی نقاط ضعف دانش‌آموزان و اصلاح روش‌های تدریس یا بازنگری کتاب‌های درسی بهره‌برداری کرد.

مهم‌ترین نکته در آزمون‌هایی مانند کنکور سراسری، ساخت آزمون و طراحی سؤال‌های مناسب و حرفة‌ای است و اصول و زیربنای ساخت آزمون‌ها را نظریه‌ها و مدل‌هایی تشکیل می‌دهند که خود این نظریه‌ها دارای کارکردها، توانمندی‌ها و پیش‌فرض‌های متفاوتی هستند که از این میان می‌توان به نظریه کلاسیک آزمون و نظریه سؤال‌پاسخ اشاره کرد. اصطلاح کلاسیک، علاوه بر اینکه به زمان شکل‌گیری مدل‌های نظریه اشاره دارد، به تقابل آن با نظریه‌های جدید روان‌سنگی، یعنی مدل‌های نظریه سؤال‌پاسخ نیز مربوط می‌شود (بن، ۲۰۰۲). گرچه نظریه کلاسیک آزمون، مدت‌زمان طولانی به جامعه روان‌سنگی خدمت کرده است، اما برخی مطالعات از جمله گالیکسن و همکاران، محدودیت‌هایی را در این نظریه و در آزمون‌های ساخته شده بر اساس آن نشان می‌دهد (دلاور و همکاران، ۱۳۸۵). ساختار و معادله نظریه کلاسیک، بیانگر آن است که مفروضه‌های آن در سطح نمره انفرادی آزمودنی تدوین شده‌اند، اما هرگز در مدل‌های آن نمره‌های انفرادی تحلیل نمی‌شوند بلکه تمرکز اصلی بیشتر بر ویژگی‌های نمره‌های آزمون در ارتباط با گروه نمونه (مجموعه‌ای از افراد) است. محدودیت دیگر نظریه کلاسیک این است که بیشتر آزمون‌مدار است تا پرسش‌مدار؛ درنتیجه تعیین سهم سؤال در پایایی و در بی‌آن، خطای معیار اندازه‌گیری آزمون پذیر نیست (عباسی و همکاران، ۱۳۹۲).

نقاط ضعف نظریه کلاسیک باعث می‌شود تفسیر مناسبی از آزمون‌ها صورت نگیرد؛ بنابراین برای داشتن یک تحلیل آزمون دقیق تر و همچنین افزایش کارایی دانش‌آموختگان باید از مدل‌ها و تکنیک‌هایی در نمره‌گذاری آزمون‌ها استفاده کرد که بتواند نقاط ضعف و قوت آنها را نشان دهد. بدون هیچ تردیدی می‌توان گفت که نظریه سؤال-پاسخ جهش بلندی به سوی آرمان‌های سنجش و اندازه‌گیری است. ریشه نظریه سؤال پاسخ را می‌توان به بینت^۱ و ترستون^۲ در اوآخر قرن ۱۸ و اوایل قرن ۱۹ اطلاق کرد (لیندن، ۲۰۱۰). نظریه سؤال-پاسخ، یک نظریه جامع آماری درباره عملکرد سؤال آزمون و آزمودنی و چگونگی سنجش توانایی‌ها است. این نظریه، نقطه مقابل نظریه کلاسیک است و بر نمره وابسته به گروه نمونه و آزمون نیست. همچنین، برآوردهای بهتری از توانایی آزمودنی به دست می‌دهد و اطلاعات بیشتری درباره آزمودنی و سؤال‌ها فراهم می‌آورد. مدل‌های IRT توابع ریاضی هستند که احتمال یک برونداد پیوسته، مانند پاسخ درست به یک سؤال را بر اساس پارامترهای آزمودنی (توانایی θ) و پارامترهای سؤال (دشواری، ضریب تشخیص و حدس) مشخص می‌کند. در حال حاضر، IRT یکی از نیرومندترین ابزارهایی است که برای تهیه و تجزیه و تحلیل تست‌ها به کار می‌رود و آن چنان گسترده و فراگیر شده که به جرئت می‌توان گفت دوره کلاسیک آزمون که ممکن است بر جمع جبری نمره‌هast است به سر آمده است تا آنجایی که بسیاری از پژوهشگران از جمله لامزدن^۴ (۱۹۷۶) و دیویسون^۵ (۱۹۸۲) توصیه کرده‌اند که مدل‌های کلاسیک باید کنار روند و مدل‌های نظریه صفت مکنون جایگزین آن شود (بخشی فرد، ۱۳۸۱).

مبانی نظری و پیشینه پژوهش

فراهانی (۱۳۷۵)، با بررسی داده‌های حاصل از اجرای سه آزمون ریاضیات، فیزیک و درس فنی که برای ۴۳۰ نفر از داوطلبان کنکور داخلی وزارت نیرو اجرا شده بود به مقایسه نظریات کلاسیک و جدید از لحاظ برآوردهای سؤال و توانایی پرداخت. نتایج، تفاوت مدل‌ها را در برآوردهای پارامتر توانایی نشان داد که مدل سه‌پارامتری نسبت به مدل کلاسیک و حتی مدل‌های یک و دو پارامتری IRT برآوردهای متفاوت‌تر و دقیق‌تری ارائه می‌دهد. واله (۱۳۹۲) نیز در پژوهش خود با عنوان «ارزیابی جامع و تعیین ویژگی‌های روان‌سنجی آزمون استعداد و آمادگی تحصیلی ویژه رشته مدیریت در کنکور سراسری ورودی مقطع کارشناسی ارشد سال‌های ۱۳۸۹-۹۰» با استفاده از نظریه کلاسیک و پرسش پاسخ نشان داد که مدل کلاسیک و مدل‌های IRT برآوردهای متفاوتی برای پارامترهای سؤال به دست می‌دهند و برآوردهای پارامترهای سؤال بر پایه مدل‌های IRT، به ویژه مدل سه‌پارامتری، دقیق‌تر از برآوردهای پارامترهای سؤال بر اساس مدل کلاسیک و مدل‌های ساده‌تر IRT است. همچنین محمدزاده رومیانی (۱۳۷۵)، داده‌های حاصل از اجرای سه آزمون زیست‌شناسی، فیزیک و ادبیات مرحله اول کنکور سراسری را تحلیل کرد. این مطالعه همراه با پژوهش فراهانی (۱۳۷۵) در مورد داده‌های حاصل از اجرای سه آزمون ریاضیات، فیزیک و درس فنی کنکور داخلی وزارت نیرو و نیز ایزانلو (۱۳۸۹) در ارزشیابی داده‌های

1. Binet

2. Thurstone

3. Linden

4. Lumsden

5. Davison

خرده‌مقیاس گرامر در بخش تخصصی دفترچه زبان انگلیسی آزمون سراسری در سال ۱۳۸۴ نشان دادند که مدل‌های IRT نسبت به مدل کلاسیک برآوردهای دقیق‌تری ارائه می‌دهد. دلاور و همکاران (۱۳۸۵)، با اجرای پژوهشی از نظر اندازه‌گیری شاخص‌های دقت آزمون بر روی ۱۰۰۰ نفر نشان دادند که نظریه سؤال-پاسخ از نظر اندازه‌گیری شاخص‌های دقت آزمون، بر نظریه کلاسیک برتری دارد. در نظریه پاسخ-سؤال، برای هر سطح توانایی، آگاهی و خطای استاندارد جداگانه‌ای به دست می‌آید که بر اساس آن می‌توان فهمید آزمون در کدام سطح توانایی، دارای بیشترین دقت و کمترین خطاست؛ مزیتی که در نظریه کلاسیک اندازه‌گیری نیست.

آشکارا مدل‌های مختلف نظریه سؤال-پاسخ از نظر دقت با یکدیگر برابر نیستند؛ به عنوان مثال، احمدی آذر (۱۳۸۷) با استفاده از مدل‌های نظریه سؤال-پاسخ، خصوصیات روان‌سنجدی آزمون‌های کنکور سراسری رشته ریاضی را بررسی کرد و دریافت که در تمام آزمون‌های کنکور مدل سه‌پارامتری برآش بهتری با مجموع داده‌ها دارد و بررسی ضرایب تشخیص، دشواری و همچنین توانایی افراد نشان داد که در نظریه سؤال-پاسخ سؤال‌های بیشتری از نظر دشواری یا قدرت تشخیص، نامناسب هستند که این نشان دهنده دقت بیشتر این نظریه نسبت به نظریه کلاسیک است. دیوجی^۱ (۱۹۸۶)، کاربرد مدل یک پارامتری راش را برای سؤال‌های چندگزینه‌ای بررسی کرده است؛ اما به رغم استفاده از مدل راش برای برآورد پارامترها در سؤال‌های چندگزینه‌ای، به نظر دیوجی به علت نبود پارامتر حدس و ضریب تشخیص یکسان در مدل راش، این کاربردها درست نیست. استیج^۲ (۱۹۹۸) در پژوهش خود، به مقایسه کارایی دو نظریه کلاسیک و سؤال-پاسخ در آزمون استعداد تحصیلی سوئد اقدام کرد. این آزمون، دارای ۵ آزمون فرعی و حاوی ۱۶ سؤال چهارگزینه‌ای است و برای انتخاب دانشجویان آموزش عالی در سوئد استفاده می‌شود. او نتیجه گرفت که مدل منطقی سه‌پارامتری با داده‌ها تناسب بهتری نشان می‌دهد. مکاین و اوفلیا^۳ (۲۰۱۱) در دانشگاه مانیلا با استفاده از یک آزمون محقق‌ساخته ۱۵ سؤالی برای سنجش استعداد یادگیری درس جبر و به کارگیری مدل یک پارامتری راش پیشنهاد دادند که در پژوهش‌ها بهتر است از مدل‌های دو و سه پارامتری استفاده شود.

اسدی و همکاران (۱۳۹۱) از مدل‌های تک‌پارامتری و سه‌پارامتری در نظریه سؤال-پاسخ برای سنجش توانایی دانش‌آموزان دبیرستان دخترانه توسط ماتریس‌های پیش‌رونده ریون استفاده کردند و به مقایسه تفاوت‌های بین برآورد پارامتر توانایی آزمودنی و برآورد پارامتر توانایی سؤال در مقیاس هوش پیش‌رونده ریون در دو مدل راش و سه‌پارامتری بر اساس تئوری سؤال-پاسخ بر روی ۴۹۸ دانش‌آموز پرداختند. نتایج این بررسی نشان داد: بین برآوردهای توانایی بر اساس دو مدل تک‌پارامتری و سه‌پارامتری تفاوت معنی‌دار وجود دارد اما بین نمره‌های توانایی‌ها در هر دو مدل همبستگی وجود دارد؛ از روی نمره‌های خام افراد می‌توان توانایی آلان را در مدل سه‌پارامتری پیش‌بینی کرد؛ از مقایسه نمره میانگین دو مدل، این نتیجه حاصل می‌شود که مدل تک‌پارامتری

1. Divgi

2. Stage

3. Macayan & Ofalia

نسبت به مدل سه‌پارامتری مقاوم‌تر است

همچنین، بقایی مقدم و روشن‌ضمیر (۱۳۸۹) با ارزشیابی یک آزمون در ک مطلب زبان انگلیسی با مدل پرسش-پاسخ چندبعدی دریافتند که مدل چهاربعدی، برازش بهتری نسبت به مدل دو بعدی؛ و مدل دو بعدی برازش بهتری نسبت به مدل تک بعدی دارد. نقی‌زاده (۱۳۹۵) در بررسی تعدادی سؤال از مباحث کتاب شیمی سوم متوجه نشان داد مدل‌های دوپارامتری و یک‌پارامتری در نظریه سؤال-پاسخ با سؤال‌های آزمون تطابق بهتری دارند. کرمی گرافی در بررسی سؤال‌های منتخب از کتاب‌های مؤسسات مبتکران و قلم‌چی از شیمی دوم متوجه و فیزیک اول متوجه نتیجه گرفت که از ۱۶۰ سؤال انتخاب‌شده فقط ۹۷ سؤال با مدل IRT دوپارامتری تطابق بهتری دارند و البته سؤالات مناسب‌تری نیز هستند. بنابراین می‌توان از این سؤال‌ها برای ایجاد بانک سؤال در آزمون‌های بعدی استفاده کرد. از طرفی، وجود عامل حدسی در حدود ۴۰ درصد برای برخی سؤال‌ها نشان داد که این سؤال‌ها کاملاً مناسب نیستند (کرمی گرافی، ۱۳۹۳ و ۱۳۹۴)، روحانی (۱۳۹۱)، سؤال‌های کارشناسی گروه علوم انسانی دانشگاه آزاد اسلامی در سال‌های ۱۳۸۷ و ۱۳۸۹ را مطالعه کرد و نشان داد فقط در ۲۱ درس از ۳۶ درس گروه علوم انسانی مفروضه نظریه سؤال-پاسخ برقرار است. تمام درس‌های بررسی شده توسط نظریه سؤال-پاسخ با مدل سه‌پارامتری برازش بهتری دارند. محاسبه پارامترهای سؤال‌ها بر اساس دو نظریه کلاسیک و سؤال-پاسخ نشان می‌دهد که این دو نظریه، همسو بوده و نتایج یکدیگر را تکمیل و تأیید می‌کنند.

مطالعاتی نیز روی تأثیر تعداد گزینه‌های سؤال در نظریه سؤال-پاسخ صورت گرفته است؛ فلسفی‌نژاد و همکاران (۱۳۹۰)، تأثیر تعداد گزینه‌های سؤال در ویژگی‌های روان‌سنجدی آزمون و توانایی برآورده شده در مدل‌های پرسش پاسخ را بررسی کردند. آنها نشان دادند که تعداد گزینه‌ها بر پارامترهای سؤال اثر ندارد و تأثیر تعداد گزینه‌ها بر ویژگی‌های روان‌سنجدی برآورده شده آزمودنی‌ها، در آزمون‌های مختلف یکسان است. شیزوکا و همکاران^۱ (۲۰۰۶) در تحقیقی در دانشگاه کانسای ژاپن از IRT برای بررسی آثار کاهش تعداد گزینه‌های سؤال‌ها بر مشخصه‌های روان‌سنجدی آزمون ورودی دانشگاه کانسای بهره گرفت. او یکی از گزینه‌های نادرست را در آزمون چهارگزینه‌ای، حذف کرد و با تبدیل آن به یک آزمون سه‌گزینه‌ای، روی گروه دیگری اجرا کرد. مقایسه پاسخ دو آزمون نشان داد که درجه سهولت و پارامتر تشخیص به طور معنی‌داری تغییر نکرد.

نظریه سؤال-پاسخ تحت تأثیر حجم نمونه است و با کاهش حجم نمونه، دقیقت و صحبت آن کاهش می‌یابد. لرد^۲ (۱۹۸۰)، طی یک مطالعه و ضمن مقایسه مدل‌های یک و دوپارامتری IRT در برآورد نمره حقیقی آزمودنی‌ها، تلاش کرد تأثیر حجم نمونه را بررسی کند. داده‌های مطالعه شامل پاسخ ۳۰۰۰ دانش‌آموز کلاس ششم به آزمون خزانه لغات متropoliten تجزیه و تحلیل شده است. نتایج مطالعه نشان داد وقتی حجم نمونه کوچک باشد، پارامتر ضریب تشخیص سؤال‌ها و پارامتر مجانب یا حدس سؤال‌ها را نمی‌توان به دقت تعیین کرد. شومیر و

1. Shizuka
2. Lord

همکاران^۱ (۲۰۱۰) با استفاده از تجزیه و تحلیل IRT تأثیر جمله‌بندی سؤال‌های امتحانی را بر عملکرد دانش آموزان بررسی کردند و به این نتیجه رسیدند که تغییرات کوچکی در جمله‌بندی سؤال‌های امتحانی می‌تواند تفاوت معنی‌داری در عملکرد دانش آموزان در پاسخ به سؤال‌های امتحانی داشته باشد.

انصارین (۱۳۷۱)، تفاوت برآورده توافقی در مدل دوپارامتری را مطالعه کرد. او با استفاده از داده‌های حاصل از اجرای آزمون هوش تهران-استنفرد-بینه (TSB) و تحلیل منحنی ویژه سؤال‌ها دریافت که نمره‌های خام یکسان دارای برآورد یکسانی از توافقی و موقعیت آزمودنی بر پیوستار مکنون نبودند. همون (۱۳۶۸) نیز در پژوهشی با استفاده از آزمون تهران-استنفرد-بینه (TSB) برآورد پارامترهای دشواری و توافقی و درواقع توافقنامه مدل راش را در برآورد پارامترها در شرایط نقض مفروضات بررسی کرد و نتیجه گرفت که مدل راش برای برآورد پارامتر دشواری سؤال‌های با ضریب تشخیص متفاوت مناسب نیست اما برای برآورد توافقی افراد مناسب و خوب است. استفاده از مدل IRT همبستگی بین نمره‌های توافقی آزمودنی‌ها در دو آزمون هوش جداگانه نشان داد بین توافقی افراد در دو آزمون جداگانه همبستگی وجود دارد (بخشی‌فرد، ۱۳۸۱).

پژوهشگران برای شناسایی کارکردهای متفاوت سؤال، سؤال‌ها گرامر در بخش تخصصی دفترچه زبان انگلیسی آزمون سراسری را با دو روش IRT و کلاسیک بررسی کردند. آنها به این نتیجه رسیدند که نظریه کلاسیک به دلیل وجود تغییرپذیری شاخص‌های آن برای شناسایی کارکرد متفاوت سؤال‌ها مفید نیستند. در مقابل، روش‌های موجود در بافت نظریه سؤال-پاسخ برای انجام این کار مفیدتر هستند (ایزانلو و حبیبی عسگرآباد، ۱۳۹۲). همچنین، عباسی و همکاران (۱۳۸۷) با مقایسه مدل‌های کلاسیک و خصیصه مکنون، در ارزیابی آزمون‌های تخصصی ورود به دوره‌های کارورزی رشته پزشکی نشان دادند که تحلیل‌های حاصل از مدل‌های خصیصه مکنون می‌توانند در جهت رفع محدودیت‌های نظریه کلاسیک آزمون مورد استفاده قرار گیرند.

نظریه سؤال-پاسخ، علاوه بر ارزشیابی آزمون، روش و ابزار مناسبی نیز برای پیش‌بینی توافقی و موفقیت افراد در آزمون‌های آتی است. رودنر^۲ (۲۰۰۹)، مطالعه‌ای جامع روی آزمون‌های GMAT^۳ برگزارشده در ایالات متحده آمریکا، طی سال‌های ۱۹۹۶-۲۰۰۴ با استفاده از IRT انجام داد و میزان قابلیت پیش‌بینی آزمون در مورد موفقیت داوطلبان در طول دوره آموزشی مدیریت MBA^۴ و همچنین مقایسه مدل انطباقی کامپیوتری و فرم مدادکاغذی آزمون GMAT را بررسی کرد و مشخص شد که به کارگیری نظریه سؤال-پاسخ در آزمون، پیش‌بینی کننده خوبی برای موفقیت افراد در ۵ سال دوره آموزشی مدیریت خواهد بود. روایی و اعتبار، توافقی آزمودنی‌ها، توابع آگاهی آزمون، احتمال سوگیری سؤال‌ها، مشخصات بانک سؤال‌ها، خطای استاندارد سؤال‌ها و دیگر ویژگی‌های روان‌سنجی نیز در این پژوهش، تحلیل و بررسی شدند.

با توجه به اهمیت آزمون کنکور سراسری در ارزشیابی و گزینش داوطلبان ورود به دانشگاه در ایران و همچنین

1. Schurmeier

2. Rudner

3. Graduate Management Admission Test

4. Master of Business Administration

توانایی روش سؤال-پاسخ، در این پژوهش، سؤال‌های شیمی در آزمون کنکور سراسری سال ۱۳۹۶ رشته علوم تجربی با روش IRT بررسی و تحلیل می‌شود. سؤال‌های پژوهش عبارت‌اند از:

- مقدار ضریب دشواری، ضریب تشخیص و عامل حدس هر سؤال در نظریه IRT و کلاسیک چند است؟
- کدام مدل یک، دو یا سه پارامتری IRT برای ارزشیابی داده‌های حاصل از اجرای آزمون کنکور سراسری برازش بهتری دارند؟
- هر یک از سؤال‌های آزمون و همچنین کل سؤال‌های شیمی کنکور سراسری ۱۳۹۶ با کدام مدل IRT سازگار‌تر هستند؟
- کدام‌یک از سؤال‌های شیمی آزمون سراسری ۱۳۹۶ برای بانک سؤال مناسب‌تر هستند؟
- میزان آگاهی هر سؤال و آگاهی کل آزمون چقدر است؟

روش پژوهش

جامعه و نمونه آماری: پژوهش حاضر از نظر هدف کاربردی و با توجه به نوع و ماهیت موضوع توصیفی-پیمایشی است. جامعه آماری پژوهش، پاسخنامه همه داوطلبان شرکت‌کننده در آزمون سراسری ورود به دانشگاه سال ۱۳۹۶ در رشته علوم تجربی بود. با توجه به اینکه نظریه‌های روان‌سنحی، بهخصوص سؤال-پاسخ، نظریه‌های نمونه بزرگ هستند، برای برآورد باثبات پارامترها، نمونه‌ای با حجم بالا لازم است. معمولاً نمونه‌های بیشتر از ۱۰۰۰ نمونه‌های بزرگ محسوب می‌شوند (یونسی، ۱۳۸۶). بنابراین برای تحلیل ۳۵ سؤال بخش شیمی آزمون سال ۱۳۹۶، از بین همه داوطلبان شرکت‌کننده در کنکور تجربی، ۵۰۰۰ پاسخنامه بهصورت تصادفی بهعنوان نمونه برای انجام تحلیل انتخاب شدند.

ابزار گردآوری داده‌ها: ابزار این پژوهش ۳۵ سؤال شیمی (دفترچه کد A-۲۰-۲۲۰ از سؤال ۲۳۶ تا سؤال ۲۷۰) در آزمون رشته علوم تجربی سال ۱۳۹۶ است که سازمان سنجش آموزش کشور بهصورت سراسری برگزار کرده است. این سؤال‌ها در ۶ کد مختلف بین آزمون‌شوندگان توزیع می‌شود. این سؤال‌ها چهارگزینه‌ای بوده و هدف این آزمون، گزینش افراد برای رشته‌های مختلف دانشگاهی بر اساس سوابق تحصیلی و نمره‌های افراد در هر یک از بخش‌های مختلف این آزمون است. با توجه به اینکه سؤال‌ها توسط متخصصان و طراحان مجبور کشور طراحی و ارزیابی می‌شود بنابراین روابی محتوایی آن قابلً توطیف این متخصصان سنجش شده است. پایایی این آزمون برای ۳۵ سؤال بررسی شده و مقدار آلفای کلی برابر ۰/۹۳۴ است که بیانگر پایایی خوب سؤال‌هاست.

فرایند اجرای پژوهش: پاسخ‌های ۵۰۰۰ آزمودنی به سؤال‌های کنکور سراسری سال ۱۳۹۶ در بخش شیمی رشته علوم تجربی، از سازمان سنجش و آموزش کشور در قالب دو فایل Excel و SPSS تحویل گرفته شد که در فایل Excel پاسخ هر آزمودنی با عبارت‌های «صحیح» و «غلط» ثبت شده بود. سپس پاسخ‌های «صحیح» هر فرد به عدد یک و پاسخ‌های «غلط یا بدون پاسخ» به عدد صفر تبدیل شدند و نمره کل هر داوطلب محاسبه

شد. نمره‌های آزمون شوندگان بر حسب نمره کل آنها (صفر تا ۳۵) طبقه‌بندی شده است که به نمره صفر عدد ۳ و به نمره ۳۵ عدد ۳+ اختصاص داده شده است. سپس جدول این اطلاعات به عنوان فایل ورودی برای نرم‌افزار SPSS و IRTPRO آماده شد و مورد استفاده و تحلیل قرار گرفت.

روش تجزیه و تحلیل داده‌ها: ابتدا مفروض تک بعدی بودن با استفاده از نرم‌افزار NOHARM و شاخص‌های RMSR^۱ و تاناکا بررسی شد که به ترتیب، مقادیر ۰/۰۰۳۵ و ۰/۹۷۳ به دست آمد. مقدار مناسب برای این شاخص‌ها به ترتیب، کوچک‌تر از ۰/۰۵ و بزرگ‌تر از ۰/۹۵ است که با توجه به مناسب بودن این ضرایب و تک بعدی بودن سؤال‌ها، نیازی به بررسی مفروضه استقلال موضوعی نیست. سپس داده‌های هر سؤال با سه مدل یک، دو و سه پارامتری IRT توسط نرم‌افزار IRTPRO تحلیل شد و شاخص‌هایی مانند درجه آزادی، خی دو، شاخص معنی‌داری sig و مقدار Log-Likelihood^۲ برای هر سه مدل نیز محاسبه شد. با مقایسه شاخص Log-Likelihood^۲ و استفاده از آزمون خی دو، بهترین مدل برای برازش داده‌های آزمون برای هر سؤال مشخص شد و پس از مشخص شدن بهترین مدل برای هر سؤال، منحنی ویژگی سؤال‌ها (ICC)، منحنی آگاهی سؤال‌ها و منحنی آگاهی آزمون و همچنین منحنی خطای استاندارد آزمون به وسیله نرم‌افزار IRTPRO ترسیم شد. میزان آگاهی هر سؤال در مدل سه‌پارامتری (بهترین مدل از نظر برازش + با داده‌ها) با استفاده از نرم‌افزار IRTPRO محاسبه شد.تابع آگاهی برای سؤال نم به صورت (θ) در مدل سه‌پارامتری به صورت زیر تعریف می‌شود:

$$I_{i(\theta)} = a_{i(\theta)}^2 \frac{(P_{i(\theta)} - c_i)^2}{(1 - c_i)^2} \frac{q_{i(\theta)}}{p_{i(\theta)}} \quad q_{i(\theta)} = 1 - p_{i(\theta)}$$

در این فرمول:

a: پارامتر ضریب تشخیص برای سؤال i

p_{i(θ)}: احتمال پاسخ درست به سؤال توسط آزمودنی با توانایی θ

q_{i(θ)}: احتمال پاسخ غلط به سؤال توسط آزمودنی با توانایی θ

θ: سطح توانایی مورد نظر

c: عامل حدس در سؤال نم است.

در صورت برقراری مفروضه استقلال موضوعی می‌توان با جمع کردن توابع آگاهی سؤال‌ها، تابع آگاهی یک آزمون را از رابطه زیر به دست آورد.

$$I(\theta) = \sum_{i=1}^N I_{i(\theta)}$$

همچنین شاخص‌های آماری درجه دشواری و ضریب تشخیص (همبستگی دو رشته‌ای نقطه‌ای) برای سؤال‌ها در نظریه کلاسیک نیز بررسی شد.

1. Root mean square of residual

جدول (۱) معیار رتبه‌بندی سؤال‌ها بر اساس مقدار پارامتر تشخیص سؤال در مدل منطقی

+ بینهایت	۱/< ۷۰	۱/۳۵ - ۱/۶۹	۰/۶۵ - ۰/۳۴	۰/۳۵ - ۰/۶۴	۰/۰۱ - ۰/۳۴	.	دامنه
کامل	خیلی قوی	قوی	متوسط	ضعیف	خیلی ضعیف	هیچ	رتبه

یافته‌ها

تمامی سؤال‌ها به صورت جداگانه با نرم‌افزار ارزشیابی شدند و در جدول (۲) شاخص‌های مدل یک، دو و سه پارامتری شامل دشواری، ضریب تشخیص، عامل حدس، خی دو، درجه آزادی و سطح معنی‌داری و همچنین شاخص‌های مدل کلاسیک برای همه سؤال‌ها آمده است. جدول (۲) نشان می‌دهد که:

- ۷ سؤال، شامل سؤال‌های ۲۳۸، ۲۴۲، ۲۴۳، ۲۵۷، ۲۵۱، ۲۶۷ و ۲۶۸ با مدل یک‌پارامتری برازش دارند زیرا دارای سطح معنی‌داری بیشتر از ۰/۰۵ هستند.
- ۹ سؤال، شامل سؤال‌های ۲۳۸، ۲۴۳، ۲۴۲، ۲۴۴، ۲۴۳، ۲۵۱، ۲۵۷، ۲۶۳ و ۲۶۷ با مدل دو‌پارامتری برازش دارند زیرا دارای سطح معنی‌داری بیشتر از ۰/۰۵ هستند.
- ۲۱ سؤال شامل سؤال‌های ۲۳۸، ۲۳۹، ۲۴۱، ۲۴۳، ۲۴۴، ۲۴۵، ۲۴۶، ۲۴۷، ۲۵۳، ۲۵۱، ۲۴۸، ۲۴۵، ۲۴۴، ۲۴۲، ۲۴۱ با مدل سه‌پارامتری برازش مناسبی دارند.
- در مدل سه‌پارامتری، آسان‌ترین سؤال ۲۴۸ و دشوارترین سؤال ۲۶۶ هستند که پارامتر *b* آنها به ترتیب کمترین (۰/۲۷) و بیشترین (۰/۴۵) است.
- در مدل سه‌پارامتری، کمترین میزان ضریب تشخیص (a) مربوط به سؤال ۲۳۹ با ضریب ۰/۳۲ و بیشترین میزان آن مربوط به سؤال ۲۵۶ با ضریب ۰/۰۷ است.
- در مدل سه‌پارامتری، سؤال‌های ۲۳۹، ۲۴۵ و ۲۶۶ از نظر قدرت تشخیص، سؤال‌های مناسبی محسوب نمی‌شوند اما سایر سؤال‌ها ضریب تشخیص بیشتر از ۰/۶۵ دارند و مناسب هستند.
- در مدل سه‌پارامتری، کمترین میزان پارامتر حدس متعلق به سؤال ۲۵۲ با ضریب ۰/۰۹ و بیشترین میزان آن مربوط به سؤال ۲۵۳ با ضریب ۰/۲۹ است.
- ۱۳ سؤال، شامل سؤال‌های ۲۳۶، ۲۳۷، ۲۴۰، ۲۴۹، ۲۴۶، ۲۴۷، ۲۵۰، ۲۵۲، ۲۵۴، ۲۵۵، ۲۵۸، ۲۶۵ و ۲۶۶ با هیچ‌یک از مدل‌های ذکر شده برازش نداشته‌اند.
- ۷ سؤال، هم با مدل یک‌پارامتری و هم با دو‌پارامتری برازش دارند.
- ۶ سؤال، هم‌زمان با هر سه مدل برازش نشان داده‌اند.

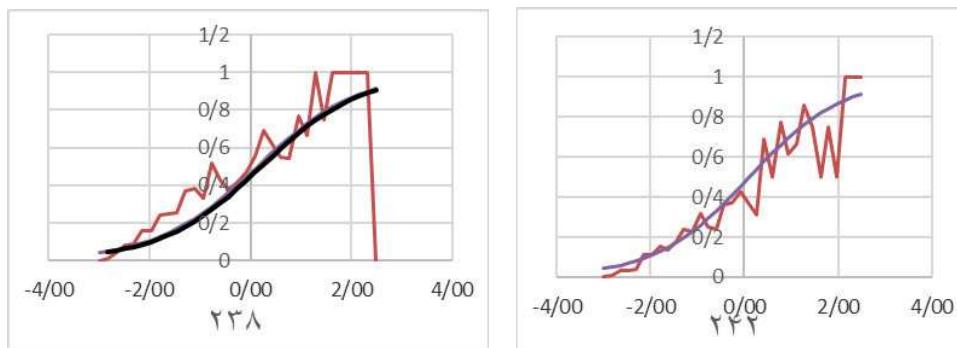
جلد (۴) ضرایب دشواری، تشخیص و حدس به دست آمده از تحلیل سوال‌ها با نظریه کلاسیک و سوال-پاسخ

IRT												کلاسیک		شماره سوال
سه‌پارامتری						دو‌پارامتری				تک‌پارامتری		a	b	شماره سوال
معنی‌داری	خی دو	c	a	b	معنی‌داری	خی دو	a	b	معنی‌داری	خی دو	b			شماره سوال
۰/۰۲۳	۱۶/۱۷	۰/۱۰	۱/۹۱	۰/۱۰	۰/۰۰۱	۲۶/۱۷	۱/۶۲	-۰/۱۰	۰/۰۰۱	۲۶/۱۷	-۰/۱۶	۰/۴۹۶	۰/۲۷۲	۲۳۶
۰...۰۰	۲۵/۴۵	۰/۲۴	۳/۱۸	-۰/۰۹	۰/۰۰۰	۳۸/۲۷	۱/۸۷	-۰/۰۵۲	۰/۰۰۰	۳۸/۲۷	-۰/۰۵۶	۰/۴۷۵	۰/۱۱۱	۲۳۷
۰/۲۹۴	۸/۴۸	۰/۱۹	۱/۵۸	۰/۰۵۹	۰/۴۶۹	۶/۶۴	۱/۰۲	-۰/۱۳	۰/۴۶۹	۶/۶۴	-۰/۱۳	۰/۰۳۱	۰/۱۶۰	۲۳۸
۰/۰۷۰	۱۳/۰۵	۰/۲۳	۰/۳۲	۴/۰۸	۰/۰۰۰	۳۸/۰۳	۰/۱۵	۳/۳۱	۰/۰۰۰	۳۸/۰۳	-۰/۰۵۹	۰/۰۲۶	۰/۱۰۲	۲۳۹
۰/۰۲۸	۱۵/۶۴	۰/۱۰	۲/۲۵	-۰/۱۴	۰/۰۰۰	۳۷/۴۹	۱/۹۸	-۰/۰۳۳	۰/۰۰۰	۳۷/۴۹	-۰/۰۵۲	۰/۰۴۰	۰/۲۷۹	۲۴۰
۰/۲۵۰	۹/۰۳	۰/۲۶	۲/۲۳	۰/۰۹۷	۰/۰۱۹	۱۶/۷۳	۰/۰۸۳	-۰/۰۳۵	۰/۰۱۹	۱۶/۷۳	-۰/۰۳۰	۰/۰۰۷	۰/۱۹۸	۲۴۱
۰/۱۰۱	۱۱/۹۷	-۰/۱۸	۳/۰۳	-۰/۰۴۱	۰/۰۴۲۶	۸/۰۹	۱/۰۵۶	-۰/۰۱	-۰/۰۴۲۶	۸/۰۹	-۰/۱۱	۰/۰۴۸۵	۰/۱۱۹	۲۴۲
۰/۶۴۳	۴/۲۶	۰/۱۰	۲/۰۰	-۰/۰۴۱	۰/۰۵۶۹	۵/۷۶	۱/۰۶۳	-۰/۰۱۹	-۰/۰۵۶۹	۵/۷۶	-۰/۰۲۸	۰/۰۵۸۷	۰/۱۹۴	۲۴۳
۰/۰۳۱۸	۸/۱۸	-۰/۲۳	۱/۱۵	۲/۰۰	-۰/۰۰۵	۲۰/۰۹	-۰/۰۲۱	۴/۰۴۲	۲۰/۰۹	۲۰/۰۹	-۰/۰۷۲	۰/۰۴۸۳	۰/۰۶۶	۲۴۴
۰/۱۹۹	۹/۸۱	-۰/۱۸	۰/۰۳۶	۲/۰۹۸	۰/۰۰۰	۴۳/۰۹	-۰/۰۲۴	۱/۰۸۱	۴۳/۰۹	۴۳/۰۹	-۰/۰۵۱	-۰/۰۲۰	۰/۱۳۹	۲۴۵
۰/۰۴۵	۱۴/۳۳	-۰/۲۳	۲/۰۹۹	-۰/۰۲۲	-۰/۰۱۸	۱۶/۰۲	۱/۰۶۶	-۰/۰۲۹	۱۶/۰۲	۱۶/۰۲	-۰/۰۳۹	-۰/۰۶۱	۰/۲۲۸	۲۴۶
۰/۰۰۹	۱۸/۰۵۲	-۰/۱۱	۱/۰۹۵	-۰/۰۰۲	-۰/۰۰۰	۲۷/۰۱۲	۱/۰۶۹	-۰/۰۲۴	۲۷/۰۱۲	۲۷/۰۱۲	-۰/۰۳۲	-۰/۰۰۷	۰/۱۶۸	۲۴۷
۰/۰۵۸	۱۳/۶۸	-۰/۱۳	۲/۰۳	-۰/۰۲۷	-۰/۰۰۶	۲۱/۰۲۳	۱/۰۸۱	-۰/۰۴۹	۲۱/۰۲۳	۲۱/۰۲۳	-۰/۰۷۴	-۰/۰۶۲۱	۰/۰۲۸۵	۲۴۸
۰/۰۱۲	۱۷/۹۲	-۰/۱۰	۲/۰۴۹	-۰/۰۵۱	-۰/۰۰۰	۴۰/۰۵۷	۲/۰۳۹	-۰/۰۸۵	۴۰/۰۵۷	۴۰/۰۵۷	-۰/۰۵	-۰/۰۵۸۷	۰/۲۵۱	۲۴۹
۰/۰۳۰	۱۵/۴۴	-۰/۲۳	۲/۰۶۴	-۰/۰۴۷	-۰/۰۰۱	۲۴/۰۷۱	۱/۰۲۸	-۰/۰۰۹	۲۴/۰۷۱	۲۴/۰۷۱	-۰/۰۰	-۰/۰۵۳۷	۰/۰۷۶	۲۵۰
۰/۱۲۹	۱۱/۰۲۲	-۰/۰۲۲	۲/۰۲۴	-۰/۰۴۵	-۰/۰۰۸۶	۱۳/۰۸۲	۱/۰۲۲	-۰/۰۰۵	۱۳/۰۸۲	۱۳/۰۸۲	-۰/۰۰۵	-۰/۰۵۷۶	۰/۰۲۵۵	۲۵۱

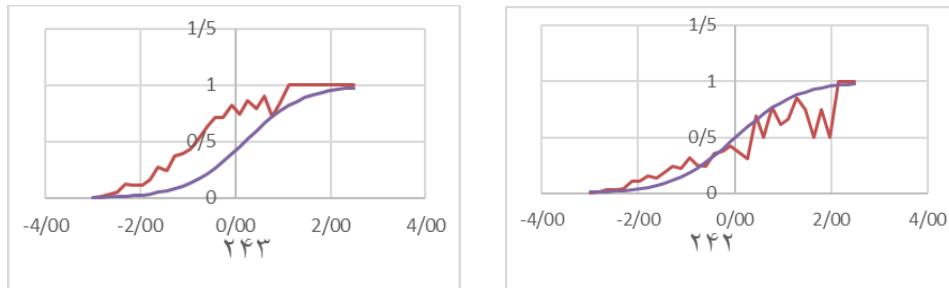
اد امه جدول (۴)

IRT												کلاسیک				
سه‌پارامتری						دویارامتری				تک‌پارامتری				a	b	شماره سؤال
معنی‌داری	خی دو	c	a	b	معنی‌داری	خی دو	a	b	معنی‌داری	خی دو	b					
۰/۰۰۰	۴۲/۶۰	۰/۰۹	۲/۲۳	-۰/۴۰	۰/۰۰۰	۷۷/۷۶	۲/۰۹	-۰/۵۴	۷۷/۷۶	۷۷/۷۶	-۰/۸۳	۰/۴۶۶	۰/۲۸۵	۲۵۲		
۰/۲۸۰	۹/۸۳	۰/۲۹	۲/۹۰	۱/۳۰	۰/۰۰۰	۲۶/۷۹	۰/۵۱	۰/۸۹	۲۶/۷۹	۲۶/۷۹	۰/۳۲	۰/۵۴۵	۰/۰۷۹	۲۵۳		
۰/۰۳۱	۱۵/۳۴	۰/۲۵	۱/۲۸	۱/۲۹	۰/۰۰۰	۲۵/۳۳	۰/۵۹	۰/۶۱	۲۵/۳۳	۲۵/۳۳	۰/۳۲	۰/۵۵۳	۰/۱۰۸	۲۵۴		
۰/۰۰۵	۱۸/۱۵	۰/۱۶	۱/۳۸	۱/۲۳	۰/۰۰۰	۳۱/۰۲	۰/۷۷	۰/۹۱	۳۱/۰۲	۳۱/۰۲	۰/۶۰	۰/۵۳۱	۰/۰۴۷	۲۵۵		
۰/۱۸۰	۱۰/۱۴	۰/۲۶	۷/۰۱	-۰/۲۳	۰/۰۰۸	۱۸/۹۳	۱/۹۳	-۰/۳۶	۱۸/۹۳	۱۸/۹۳	-۰/۳۴	۰/۶۲۱	۰/۱۶۵	۲۵۶		
۰/۱۵۹	۱۰/۵۴	۰/۱۴	-۰/۹۷	۱/۶۷	-۰/۱۰۹	۱۱/۷۴	-۰/۶۱	۱/۳۵	۱۱/۷۴	۱۱/۷۴	-۰/۶۲	۰/۵۵۳	۰/۰۳۶	۲۵۷		
۰/۰۱۳	۱۷/۶۳	۰/۲۰	۳/۸۰	-۰/۲۹	-۰/۰۰۱	۲۵/۱۴	۱/۸۲	-۰/۲۰	۲۵/۱۴	۲۵/۱۴	-۰/۱۳	۰/۵۹۳	۰/۱۱۲	۲۵۸		
۰/۰۶۰	۱۳/۵۱	۰/۱۶	۱/۶۹	-۰/۸۱	-۰/۰۰۶	۱۹/۸۲	۱/۰۲	-۰/۴۴	۱۹/۸۲	۱۹/۸۲	-۰/۴۴	۰/۵۳۵	۰/۱۷۶	۲۵۹		
۰/۱۴۷	۹/۵۰	-۰/۲۰	۱/۴۳	-۰/۵۶	-۰/۰۰۶	۱۹/۷۶	-۰/۹۵	-۰/۰۴	۱۹/۷۶	۱۹/۷۶	-۰/۰۴	۰/۵۴۲	۰/۱۷۵	۲۶۰		
۰/۰۷۵	۱۲/۸۵	-۰/۲۳	۱/۳۵	۲/۰۹	۰/۰۰۰	۴۵/۵۶	-۰/۳۵	۲/۳۳	۴۵/۵۶	۴۵/۵۶	-۰/۹۲	۰/۴۱۶	۰/۱۴۸	۲۶۱		
۰/۱۳۳	۹/۷۸	-۰/۲۱	-۰/۹۶	۱/۰۲	-۰/۰۰۰	۲۷/۸۲	-۰/۶۳	-۰/۳۱	۲۷/۸۲	۲۷/۸۲	-۰/۲۳	۰/۵۵۹	۰/۱۹۰	۲۶۲		
۰/۱۲۴	۱۱/۳۴	-۰/۱۷	۲/۰۲	-۰/۰۹	-۰/۰۴۴	۱۵/۸۹	۱/۰۰	-۰/۲۷	۱۵/۸۹	۱۵/۸۹	-۰/۲۷	۰/۵۳۲	۰/۱۸۰	۲۶۳		
۰/۲۴۶	۹/۰۸	-۰/۱۴	-۰/۷۳	۲/۴۰	-۰/۰۰۰	۲۹/۸۸	-۰/۴۴	۲/۱۸	۲۹/۸۸	۲۹/۸۸	-۰/۰۳	۰/۵۵۱	۰/۰۶۲	۲۶۴		
۰/۰۱۹	۱۶/۷۳	-۰/۱۸	۲/۹۶	-۰/۲۰	-۰/۰۰۳	۲۳/۴۹	۱/۸۵	-۰/۱۰	۲۳/۴۹	۲۳/۴۹	-۰/۱۲	۰/۵۸۲	۰/۱۰۵	۲۶۵		
۰/۰۰۳	۲۱/۱۹	-۰/۲۱	-۰/۳۷	۸/۴۵	-۰/۰۰۰	۳۴/۱۳	-۰/۰۷	۱۶/۱۱	۳۴/۱۳	۳۴/۱۳	-۰/۹۲	۰/۵۴۰	-۰/۰۳۸	۲۶۶		
۰/۰۲۹	۱۵/۵۱	-۰/۱۴	۱/۴۵	-۰/۴۱	-۰/۰۵۴	۱۳/۸۳	۱/۱۰	-۰/۰۹	۱۳/۸۳	۱۳/۸۳	-۰/۱۰	۰/۵۰۶	۰/۱۹۸	۲۶۷		
۰/۱۹۴	۹/۸۹	-۰/۱۲	۱/۴۲	-۰/۷۶	-۰/۱۲۳	۱۱/۳۶	۱/۰۲	-۰/۴۸	۱۱/۳۶	۱۱/۳۶	-۰/۴۸	۰/۴۴۲	۰/۰۸	۲۶۸		
۰/۲۴۴	۹/۱۲	-۰/۲۱	۱/۲۷	۱/۲۵	-۰/۰۲۳	۱۵/۵۷	-۰/۶۵	-۰/۶۸	۱۵/۵۷	۱۵/۵۷	-۰/۳۸	۰/۵۴۱	-۰/۰۷۲	۲۶۹		
۰/۱۲۰	۱۱/۴۴	-۰/۱۳	۲/۳۶	-۰/۳۲	-۰/۰۳۹	۱۴/۷۷	۱/۰۸	-۰/۰۳	۱۴/۷۷	۱۴/۷۷	-۰/۱۴	۰/۵۲۹	-۰/۱۴۵	۲۷۰		

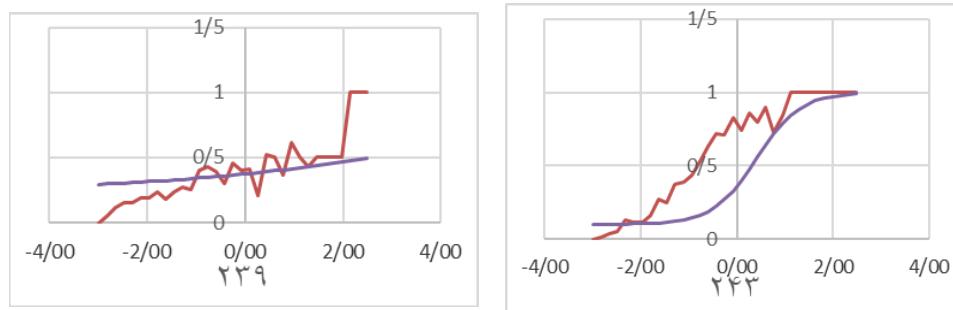
در زیر منحنی ویژه سؤال برای تعدادی از سؤال‌ها در مدل‌های مختلف رسم شده است. شکل‌های (۱) و (۲) به ترتیب، بهترین برازش با مدل تک‌پارامتری و دوپارامتری را نشان می‌دهند. در شکل (۳) سؤال‌ها با مدل سه‌پارامتری برازش شده‌اند که در آنها آسان‌ترین، سخت‌ترین، سؤال‌های با بیشترین و کمترین ضریب تشخیص و عامل حدس نشان داده شده‌اند. در این نمودارها محور افقی توانایی (θ) و محور عمودی (p) و (e) را نشان می‌دهد. نمودارهای (p) به صورت خط پیوسته قرمزرنگ و دندانه‌دار و برازش با مدل به صورت خط پیوسته بنفسنگ نشان داده شده است.

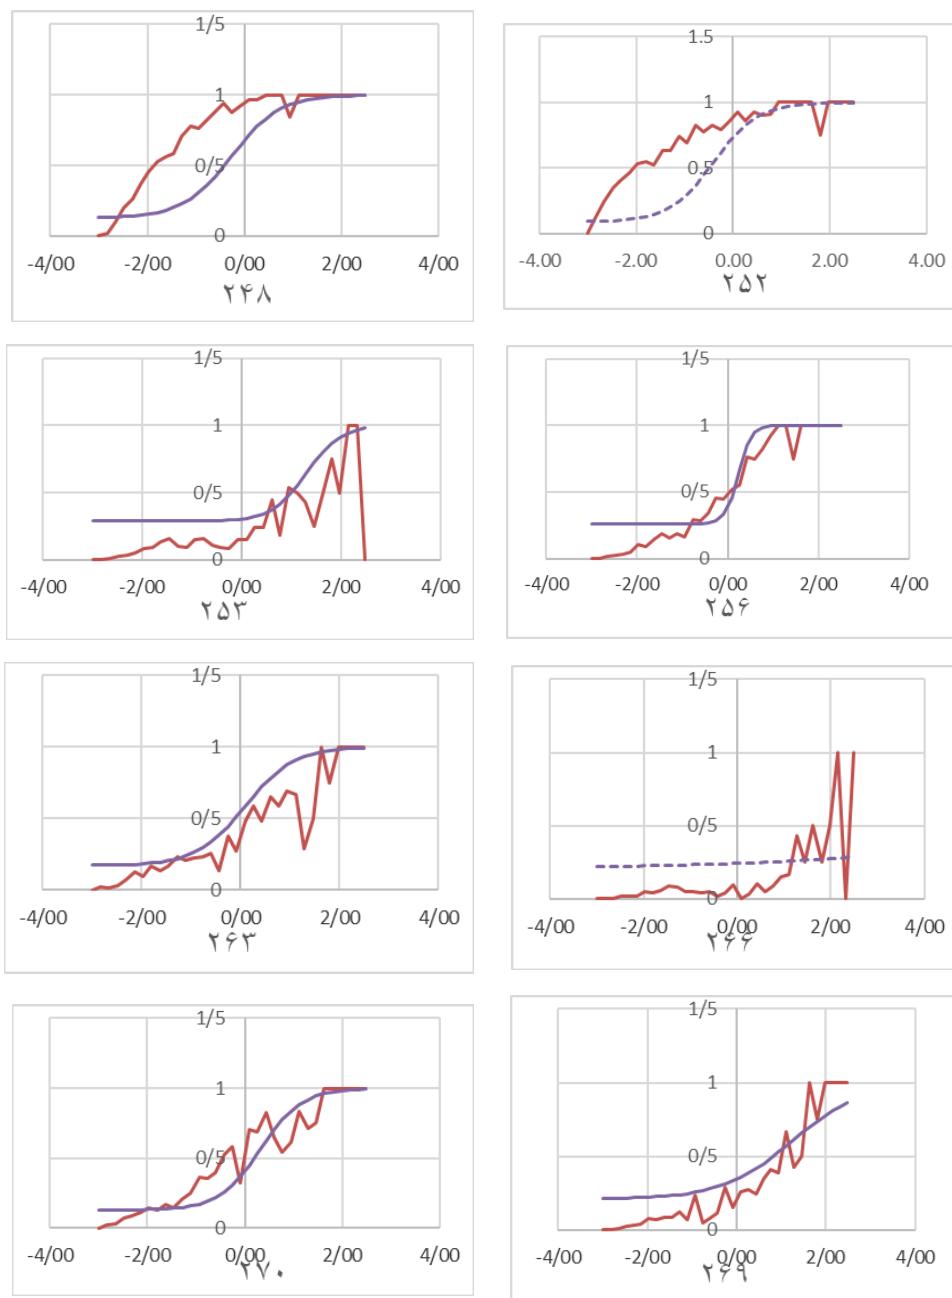


شکل (۱) منحنی ویژگی تعدادی از سؤال‌ها با مدل یک‌پارامتری



شکل (۲) منحنی ویژگی تعدادی از سؤال‌ها با مدل دوپارامتری





شکل (۳) منحنی ویژگی تعدادی از سؤال‌ها با مدل سه‌پارامتری

سؤال ۲۶۶ با $b=8/45$ دشواری بسیار زیادی دارد و نمودار آن تقریباً افقی و شیب کمی ($a=0/37$) دارد و با توجه به جدول (۲) می‌توان گفت که قدرت تشخیص سؤال ضعیف است. از طرفی، مجانب پایینی نمودار بزرگ است و عامل حدس در این سؤال $0/21$ است یعنی شناس افراد با توانایی کم نیز برای پاسخ دادن حدسی به این سؤال بالاست. سطح معنی‌داری این سؤال $0/003$ است که بسیار کمتر از $0/05$ است و نشانه عدم برازش این سؤال با مدل سه‌پارامتری است. این سؤال با هیچ مدلی برازش نداشته و سؤال نامناسبی است و بهتر است در سال‌های بعد از طرح سؤال‌های مشابه با این سؤال صرف‌نظر شود.

در سؤال ۲۵۶ دشواری متوسط و $b=0/23$ است اما شیب بسیار زیادی دارد ($a=7/01$) بنابراین، شکل منحنی آن تقریباً Δ شکل است و مطابق جدول (۲) می‌توان گفت قدرت تشخیص این سؤال خیلی خوب است. مجانب پایینی نمودار بزرگ و عامل حدس در این سؤال $0/26$ است یعنی شناس افراد با توانایی کم نیز برای پاسخ دادن حدسی به این سؤال بالاست. سطح معنی‌داری این سؤال $0/18$ است که بیشتر از $0/05$ است و نشانه برازش خوب این سؤال با مدل سه‌پارامتری است؛ بر این اساس، به‌طور کلی می‌توان گفت این سؤال مناسب است.

بررسی برازش مدل‌های مختلف با استفاده از RMSEA

در جدول (۳)، مقادیر RMSEA در مدل‌های مختلف نشان داده شده است. شاخص RMSEA در هر مدل، هرچه به صفر نزدیک‌تر باشد سؤال‌های با آن مدل برازش بهتری دارند. مقدار این شاخص در مدل سه‌پارامتری $0/06$ و از همه کمتر است بنابراین، سؤال‌های آزمون شیمی سال ۱۳۹۶ با مدل سه‌پارامتری برازش بهتری دارند. نمودارهای منحنی ویژگی سؤال در شکل (۳) نیز نشان‌دهنده این مورد است.

جدول (۳) مقادیر RMSEA در مدل‌های مختلف برای بررسی برازش کل آزمون با هر مدل

RMSEA	(p)	احتمال	درجه آزادی	χ^2	بیشینه درست‌نمایی	مدل
$0/08$	$0/0001$	۵۹۴	۱۸۷۲۹/۶۹	۵۲۷۵۱/۰۲	۱ پارامتری	
$0/07$	$0/0001$	۵۶۰	۱۴۰۴۹/۳۳	۵۱۲۰۹/۶۵	۲ پارامتری	
$0/06$	$0/0001$	۵۲۵	۱۰۸۷۸/۵۰	۵۰۸۹۳/۰۷	۳ پارامتری	

مقایسه برازش داده‌ها با مدل‌های مختلف

برای مقایسه مدل‌های مختلف IRT و تعیین بهترین مدل از میان مدل‌های یک و دو و سه پارامتری از آزمون خی دو استفاده شده است. در این آزمون، فرضیه به این قرار است که مدل دارای پارامترهای بیشتر نسبت به مدل دارای پارامترهای کمتر، برازش بهتری با داده‌ها دارد. این آزمون به صورت زیر استفاده می‌شود.

$((\text{مدل ب}) - \text{Loglikelihood}_2) - ((\text{مدل الف}) - \text{Loglikelihood}_2) = \chi^2$

جدول (۴) مقایسه برآذش داده‌ها با مدل‌های مختلف با استفاده از آزمون خی دو

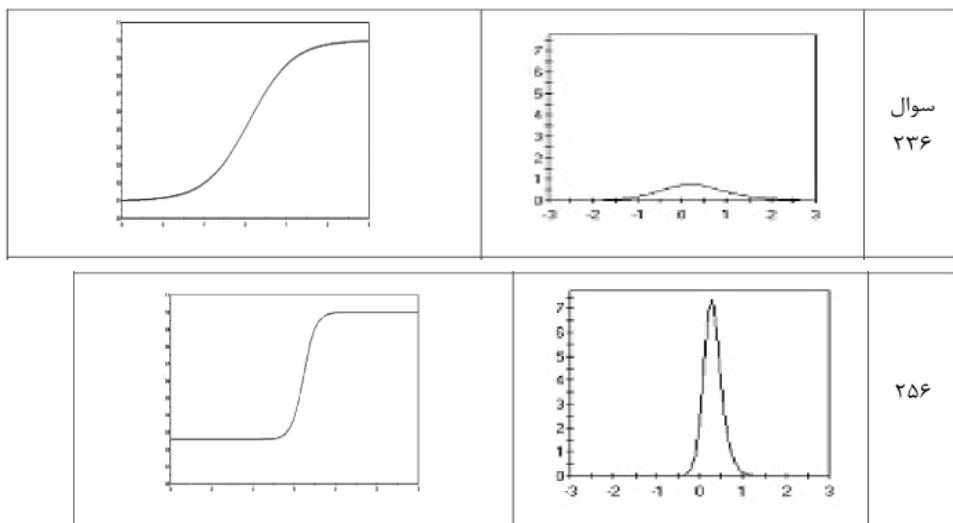
خی دو	-Loglikelihood			مقایسه یک با دو پارامتری
	سه پارامتری	دو پارامتری	یک پارامتری	
۱۵۴۱/۳۷		۵۱۲۰۹/۶۵	۵۲۷۵۱/۰۲	مقایسه یک با دو پارامتری
۳۱۶/۵۸	۵۰۸۹۳/۰۷	۵۱۲۰۹/۶۵		مقایسه دو با سه پارامتری

مقدار مجاز خی دو در جدول‌های استاندارد برای درجه آزادی ۳۵ و سطح اطمینان ۹۹ درصد ۵۷/۳۴۲ است. مقدار خی دو به دست آمده در جدول (۴) برای مقایسه مدل یک و دو پارامتری ۱۵۴۱/۳۷ و بزرگ‌تر از مقدار مجاز است؛ به عبارتی برآذش داده‌ها با مدل دوپارامتری با برآذش آنها با مدل یک‌پارامتری متفاوت است. همچنین، چون مقدار بیشینه درست‌نمایی در مدل دوپارامتری کمتر است پس مدل دوپارامتری نسبت به مدل تک‌پارامتری، برآذش بهتری با این مجموعه از داده‌ها دارد. همچنین با استدلال مشابه، می‌توان گفت که مدل سه‌پارامتری از مدل دوپارامتری برای برآذش سؤال‌ها بهتر است.

نمودار آگاهی و منحنی ویژه سؤال‌ها در مدل سه‌پارامتری

برای تخمین نقش هر سؤال در میزان آگاهی‌دهندگی آن سؤال روی پیوستار توانایی، ازتابع آگاهی سؤال استفاده می‌شود که در شکل (۴) بهترین وضعیت‌ترین سؤال از نظر آگاهی در منحنی ویژگی این دو سؤال آمده است. تابع آگاهی سؤال در سمت راست و منحنی ویژگی آن در سمت چپ آمده است. در نمودار آگاهی، محور افقی، توانایی و محور عمودی، میزان آگاهی سؤال است و در منحنی ویژگی سؤال، محور افقی، توانایی و محور عمودی، احتمال پاسخ درست به سؤال $P(\theta)$ است.

نمودار آگاهی هر سؤال، میزان آگاهی آن را روی پیوستار توانایی مشخص می‌سازد. همان‌طور که دیده می‌شود هرچه شیب منحنی یا ضریب تشخیص یک سؤال بیشتر باشد، آگاهی آن سؤال نیز افزایش می‌یابد؛ به این معنی که این سؤال‌ها قادر به تفکیک افراد دارای سطوح مختلف توانایی هستند پس سؤال‌های مناسبی نیز خواهند بود.



شکل (۴) نمودار تابع آگاهی و منحنی ویژه سؤال برای دو سؤال در مدل سه‌پارامتری

سؤال‌های ۲۳۹، ۲۴۵ و ۲۶۶ شیب کمتر از $0/۶۵$ دارند و نمودار آگاهی آنها مماس بر محور توانایی است. سؤال‌های ۲۴۴، ۲۵۴، ۲۵۵، ۲۵۷، ۲۶۱، ۲۶۲، ۲۶۴ و ۲۶۹ دارای شیب $0/۶۵ < a < 1/۳۵$ هستند و نمودار آگاهی آنها به سختی قابل تشخیص است. سؤال‌های ۲۴۸، ۲۶۷، ۲۶۰، ۲۵۹، ۲۳۸ و ۲۶۸ دارای شیب $1/۳۵ < a < 1/۷$ هستند و نمودار آگاهی آنها پهن و بدون قله نوک‌تیز است و دامنه آگاهی آنها نسبتاً زیاد است. هرچه سؤال سخت‌تر باشد و مقدار پارامتر b در آن بیشتر باشد، نمودار آگاهی به سمت راست کشیده می‌شود و هرچه مقدار b کمتر باشد نمودار به سمت چپ کشیده می‌شود. سؤال‌های ۲۳۶، ۲۳۷، ۲۴۱، ۲۴۰، ۲۴۳، ۲۴۲، ۲۴۷ و ۲۴۸ آگاهی آنها دارای کم و مقدار آگاهی زیاد و قله نوک‌تیزتر و مرتفع‌تر است که از میان آنها سؤال ۲۵۶ دارای بیشترین شیب و بیشترین آگاهی است. هر چقدر ضریب تشخیص (شیب) یک سؤال بزرگ‌تر باشد تابع آگاهی آن به صورت یک قله مرتفع و باریک‌تر ظاهر خواهد شد و بر عکس، سؤال‌های با ضریب تشخیص کمتر، به شکل یک تپه پهن و کمارتفع درخواهد آمد؛ به عبارتی تابع آگاهی سؤال با ضریب تشخیص آن را بطور مستقیم دارد.

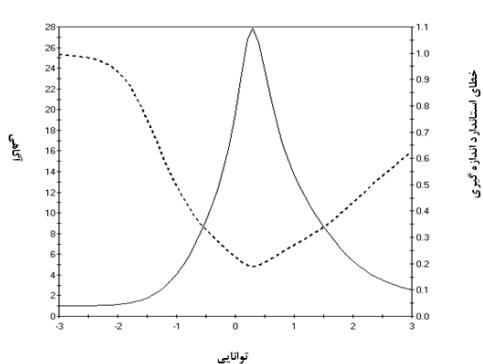
منحنی ویژه کل آزمون در مدل سه‌پارامتری

از آنجاکه مدل سه‌پارامتری با سؤال‌های بیشتری برآش دارد و شاخص RMSEA کوچک‌تری در مقایسه با سایر مدل‌ها دارد منحنی ویژگی کل آزمون یعنی تمامی ۳۵ سؤال با استفاده از مدل سه‌پارامتری تحلیل شد که شکل آن در شکل (۵) رسم شده است.

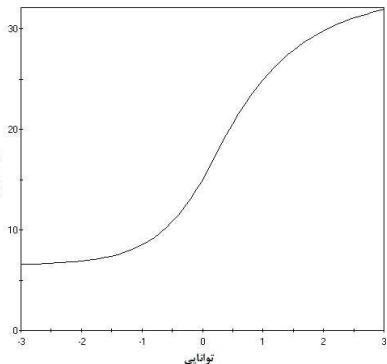
این نمودار به شکل ۵ با یک شیب تند و ضریب دشواری $3/0$ است؛ بنابراین می‌توان گفت که دشواری آزمون شیمی نسبتی متعادل بوده است زیرا ضریب دشواری در یک آزمون با دشواری متوسط، در نقطه صفر قرار می‌گیرد. همچنین شیب تند نمودار نشان می‌دهد مجموعه سؤال‌های آزمون شیمی کنکور سراسری سال ۱۳۹۶ رشته تجربی قدرت تشخیص بسیار خوبی دارد و با توجه به شیب منحنی بیشترین قدرت تشخیص بین سطوح توانایی $۰/۰$ - $۰/۲$ است. در ادامه مقاله، تأثیر این ناحیه بر تابع آگاهی آزمون مشخص خواهد شد. همچنین از شکل (۵) می‌توان دریافت که عامل حدس آزمون نسبتاً زیاد است که از معایب این آزمون است.

تابع آگاهی کل آزمون در مدل سه‌پارامتری

تابع آگاهی، اطلاعات مفیدی را در مورد ارزشیابی آزمون‌شوندگان در اختیار قرار می‌دهد. در شکل (۶) تابع آگاهی کل آزمون (منحنی پیوسته) و خطای استاندارد اندازه‌گیری (منحنی نقطه‌چین) رسم شده است.



شکل (۶) تابع آگاهی کل آزمون



شکل (۵) منحنی ویژه کل آزمون با مدل سه‌پارامتری

نمودار (۶) در مدل سه‌پارامتری نشان می‌دهد که این آزمون برای داوطلبان کنکوری که توانایی آنها در دامنه -1 - $2/5$ قرار دارد مناسب است زیرا همان‌طور که شکل (۵) نشان می‌دهد رشد و افزایش منحنی ویژه آزمون در این ناحیه است؛ یعنی در این ناحیه از توانایی با تغییر توانایی آزمون‌شوندگان، میزان پاسخ صحیح آنها نیز تغییر می‌کند. به عبارتی، با افزایش قدرت تشخیص آزمون، تابع آگاهی آن نیز افزایش می‌یابد. بررسی آمار توصیفی و فراوانی داوطلبان نیز نشان داد که حدود $8/5$ درصد از داوطلبان کنکور سراسری این سال در این ناحیه قرار می‌گیرند و درصد پاسخ درست آنان به سؤال‌های شیمی در محدوده $۹۱/۵$ - $۳۲-۹۱$ درصد بوده است. از طرفی، حدود ۹۱ درصد از داوطلبان نیز در ناحیه با توانایی کمتر از -1 - $۰/۱$ درصد بوده است. کمتر از ۳۲ درصد است و آزمون میزان آگاهی بسیار کمی در مورد آنها در اختیار ما قرار می‌دهد. همچنین

از نمودار پیداست که آزمون بیشترین میزان آگاهی و اطلاعات را در توانایی $0/3$ فراهم می‌آورد. بیشینه یا قله نمودار آگاهی در نقطه عطف منحنی ویژه آزمون قرار می‌گیرد که تغییرات شیب منحنی در این ناحیه بیشترین مقدار است و در نمودار (5) نیز نشان داده است.

بحث

یافته‌های پژوهش نشان می‌دهد سؤال ۲۴۸ آسان‌ترین سؤال است زیرا در مورد محاسبات ساده استوکیومتری و واکنشگر محدود‌کننده بدون نیاز به ماشین حساب است. اما سؤال ۲۶۶ دشوارترین سؤال در مورد محاسبه pH است که علاوه بر دانش شیمی به مهارت و دانش ریاضی برای محاسبه لگاریتم اعداد بدون استفاده از ماشین حساب نیاز دارد و همین دشواری بسیار زیاد سؤال سبب کاهش شدید ضریب تشخیص این سؤال شده است؛ بنابراین طراحی چنین سؤال‌هایی در سال‌های آینده پیشنهاد نمی‌شود یا اینکه دبیران شیمی نحوه محاسبه لگاریتم بدون استفاده از ماشین حساب را به دانش‌آموزان آموزش دهند. سؤال ۲۵۶ در مورد تهییه محلول‌های رقیق از محلول‌های غلیظ است که باید از فرمول ریاضی متفاوت و پیچیده‌تر و لحاظ کردن درصد محلول در مقیاس ۱۰۰ استفاده شود. بنابراین حل این سؤال اندکی سخت‌تر است اما آنچنان نیست که ضریب سختی سؤال را بسیار زیاد کند، پس ضریب تشخیص سؤال در محدوده بسیار مناسبی قرار می‌گیرد و بهترین سؤال این آزمون است. پیشنهاد می‌شود از سؤال‌های محاسباتی دارای چندین فرمول برای حالات مختلف و با عملیات ریاضی نه‌چندان سخت در سال‌های آینده بیشتر استفاده شود. سؤال‌های ۲۴۵ و ۲۳۹ سؤال‌های ترکیبی از موضوعات مختلف هستند و برای پاسخ درست به سؤال باید هم‌زمان به چندین مبحث شیمی تسلط داشت. مثلاً سؤال ۲۴۵ از مباحث گروه‌های عاملی، قلمرو الکترونی و فرمول‌های ساختاری طراحی شده است و در طرح سؤال ۲۳۹ از مباحث آرایش الکترونی، نیروهای بین مولکولی، خاصیت تناوبی انرژی یونش و ارتباط آن با آرایش الکترونی استفاده شده است. این سؤال‌ها به حدی دشوار و سخت هستند که تعداد افراد بسیار بسیار کمی توانایی پاسخ به آن را دارند؛ بنابراین به دلیل ضریب دشواری بسیار زیاد، ضریب تشخیص آنها خیلی کوچک است و سؤال‌های مناسبی به شمار نمی‌آیند و باید از طرح سؤال بسیار سخت و پیچیده پرهیز شود. در عوض از سؤال‌های ترکیبی مشکل از دو موضوع استفاده شود. علی‌رغم اینکه ۱۳ سؤال با هیچ‌یک از مدل‌های IRT برآش نداشتند اما بررسی شاخص RMSEA نشان داد که مدل سه‌پارامتری با کل آزمون و سؤال‌های بیشتری برآش دارد و تحلیل منحنی ویژه کل آزمون با استفاده از مدل سه‌پارامتری، ضریب دشواری $0/3$ را نشان می‌دهد و بیانگر دشواری نسبتاً متعادل آزمون شیمی است. همچنین، شیب منحنی ویژه کل آزمون قدرت تشخیص بسیار خوبی را برای آزمون شیمی نشان می‌دهد که بیشترین قدرت تشخیص، برای سطوح توانایی $۰/۵$ -تا ۲ است. این منحنی بیانگر عامل حدس نسبتاً زیاد آزمون است که از معایب این آزمون است. بررسی تابع آگاهی کل آزمون نشان می‌دهد این آزمون برای داوطلبان کنکوری که توانایی آنها در دامنه ۱ -تا $۲/۵$ قرار

دارد مناسب است که حدود ۸/۵ درصد از داوطلبان کنکور سراسری این سال در این ناحیه قرار می‌گیرند و درصد پاسخ درست آنان به سؤال‌های شیمی در محدوده ۹۱/۵-۳۲ درصد بوده است. بیشترین میزان آگاهی و اطلاعات این آزمون برای داوطلبان با توانایی ۰/۳ است.

نتیجه‌گیری

آزمون شیمی کنکور سراسری ۱۳۹۶ با مدل سه‌پارامتری برازش بهتری نشان می‌دهد. از مزایای آن می‌توان گفت که بیشترین آگاهی این آزمون برای داوطلبان دهک بالا یعنی پاسخ‌های صحیح در محدوده ۹۱/۵-۳۲ درصد است و ضریب دشواری و ضریب تشخیص نسبتاً معادلی دارد اما پارامتر حدس آن نسبتاً زیاد است که از معایب این آزمون است. با توجه به یافته‌های این پژوهش پیشنهاد می‌شود سؤال‌های دارای ضرایب دشواری و تشخیص و عامل حدس مناسب در بانک سؤال‌های سازمان سنجش کشور قرار گیرند و با تحلیل سالیانه کنکور سراسری، بانک غنی از سؤال‌های مناسب شیمی تهیه شود و در آزمون‌های سال‌های آینده و آزمون‌های آزمایشی و استخدامی و المپیادها و ... از این بانک استفاده شود. همچنین به طراحان سؤال کنکور پیشنهاد می‌شود با مطالعه و الگوبرداری از سؤال‌هایی که در این پژوهش و پژوهش‌های مشابه، مناسب تشخیص داده شده‌اند، طراحی سؤال‌های آینده با کیفیت بهتری انجام دهند و مؤلفان کتب درسی و دبیران شیمی نیز می‌توانند با استفاده از یافته‌های تحلیل سؤال‌ها، نقاط ضعف در یادگیری دانش‌آموختان و همچنین ابهام‌های کتاب‌های درسی را مورد بازنگری قرار دهند و به اصلاح روش‌های تدریس و متن کتاب‌های درسی اقدام کنند.

تقدیر و تشکر

بدین‌وسیله از جناب آقای دکتر رضا محمدی، معاون محترم امور آزمون‌های سازمان سنجش آموزش کشور، که داده‌های اولیه پژوهش و پاسخنامه‌های داوطلبان را در اختیار پژوهشگر قرار دادند صمیمانه سپاسگزاری می‌شود.

References

- Ahmadi, A. (2008). *Scoring using classical theory techniques and its comparison with the models of Item-Response theory in the bachelor's entrance exam in mathematics*. Master's Thesis, Tehran. Allameh Tabatabaei University. [in Persian]
- Ansarin, A. (1992). *Estimation of the Item characteristic curve and the ability of the subjects in Tehran-Stanford-Binet scale based on the two-parameter model of the Latent trait*. Master's Thesis, Islamic Azad University. [in Persian]
- Asadi, K., Hooman, H. A., & Liaqat, R. (2012). Comparison of one and three-parameter models of Item-Response theory in assessment the ability of high school girls by Raven's progressive matrices. *Journal of Psychological Research*, 4(13), 71-89. [in Persian]
- Bakhshifard, S. (2002). *Application of IRT model in comparison between IQ test ability scores*

- at Raven progressive matrices. Master's Thesis, Islamic Azad University, Central Tehran Branch. [in Persian]
- Baqaei Moghadam, P., & Roshanzamir, M. (2010). A Study of the Divisibility of the Comprehension Structure in a Foreign Language Using the Multidimensional Item response theory. *Journal of Language & Translation Studies (JLTS)*, 3, 1- 20. [in Persian]
- Delavar, A., Moghadamzadeh A., & Motiei Langroudi S. T. (2006). Comparison of classical measurement model and non-parametric Item response theory models in terms of question characteristics. *Quarterly Journal of Educational Innovations*, 18, 41-56. [in Persian]
- Divgi, D. R. (1986). Does the Rasch model really work for multiple choice items? Not if you look closely. *Journal of Educational Measurement*, 23(4), 283-298.
- Falsafinejad, M. R., Delavar, A., Farrokhi, N. A., & Mohagheghi, M.A. (2013). Comparison of classic and latent trait models in the evaluation of specialized entrance exams for medical internships in Tehran. *Iranian Journal of Medical Education*, 13(3), 167-178. [in Persian]
- Farahani, M. (1996). *Comparison of classic and and IRT models in terms of question parameters and ability estimating*. Master's Thesis, Allameh Tabatabaei University. [in Persian]
- Hooman, H. A. (1989). Tehran-Stanford-Binet Individual Intelligence Test. *Quarterly Journal of (Educational Sciences, University of Tehran, Special Issue of Psychometrics*, New Volume, (1-4. [in Persian]
- Izanloo, B., & Habibi, M. (2008). Introduction to new measurement approaches in the field of psychology and educational sciences. *Journal of Psychology & Education*, 8, 135-165. [in Persian]
- Karami Gazafi, A., & Niknam Z. (2014). Evaluation of mobtakeran Book Questions by IRT Method in the Periodic Properties of Elements topics from the Second Year High School Chemistry Book, *Sixth National Conference on Education*, Shahid Rajae Teacher Training University, Tehran, Iran. [in Persian]
- Karami Gazafi, A., & Niknam Z. (2015). Evaluating the questions of ghalam-Chi book on light and light reflectiontopics in the first year physics high school textbook, *7th National Conference on Education*, Shahid Rajae Teacher Training University,Tehran, Iran. [in Persian]
- Karimi, B., Falsafinejad, M., & Dartaj, F. (2011). The effect of the number of question options on the psychometric properties of the test and the estimated ability in the the Item response theory and classical models. *Educational Measurement*, 6(2). [in Persian]
- Linden, W.J., Van Der. (2010). Item Response Theory, *International Encyclopedia of Education*, 81-89.
- Lord, F. M. (1980). *Applications of item response theory to practical testing problems*. Routledge.

- Macayan, J., & Ofalia, B. (2011). Determining experts and novices in college algebra: A psychometric test development and analysis using the Rasch model (1PL-IRT). *Educational Measurement & Evaluation Review*, 2, 62-76.
- Mahmoudian, H. (2011). *Setting up a question bank in the mathematics section in the university entrance exam at 2010 based on the Item response theory*. Master's Thesis, Faculty of Psychology and Educational Sciences, Allameh Tabatabai University. [in Persian]
- Maleki, H. (2013). *Introduction to curriculum planning*. Tehran: The Organization for Researching and Composing University Textbooks in the Humanities (SAMT). [in Persian]
- Mohammadzadeh Romiani, M. (1996). *The Question Selection Methods in the Classical and IRT Models*, Master's Thesis, Faculty of Psychology and Educational Sciences, Allameh Tabatabaei University. [in Persian]
- Nafisi, G. (1997). *Assessment and Evaluation*. Tehran: Azad University, North Branch. [in Persian]
- Naghizadeh, F. (2016). *Evaluation of several questions in chemical reactions, stoichiometry and chemical Thermodynamics topics using Item response theory in junior high school chemistry*, Master's Thesis, shahid Rajaee Teacher Training University, Tehran, Iran. [in Persian]
- Rouhani, M. (2012). *The analysis of Content and psychometric properties of the Islamic Azad University entrance exam for humanities science at 2007-2009*, Master's Thesis, Faculty of Psychology and Educational Sciences, Allameh Tabatabaei University. [in Persian]
- Rudner, L. M. (2009). Implementing the graduate management admission test computerized adaptive test. In *Elements of adaptive testing*, Springer, New York, 151-165.
- Schurmeier, K. D., Atwood, C. H., Shepler, C. G., & Lautenschlager, G. J. (2010). Using item response theory to assess changes in student performance based on changes in question wording. *Journal of Chemical Education*, 87(11), 1268-1272.
- Sepasi, H. (2003). Comparison of concepts and assumptions between classic and Item response theory in the construction of psychological and educational tests. *Journal of Educational Sciences & Psychology*, 3(3 , 4). [in Persian]
- Shizuka, T., Takeuchi, O., Yashima, T., & Yoshizawa, K. (2006). A comparison of three-and four-option English tests for university entrance selection purposes in Japan. *Language Testing*, 23(1), 35-57.
- Stage, C. (1998). A Comparison between Item Analysis Based on Item Response theory. A Study of SWESAT subtest RCE. *Journal of Educational Measurement*, 31.
- Valeh, M. (2013). *The Comprehensive evaluation and determination of psychometric properties of aptitude and academic readiness test for management major in the entrance exam for master's*

- degree using classical theory and Item response theory (IRT) at 2010-2011. Master's Thesis, Faculty of Psychology and Educational Sciences. Allameh Tabatabai University. [in Persian]
- Yen, A. (2002). *Introduction to measurement theory*. Long Grove IL: waveland press.
- Younesi, J. (2007). *Study of Psychometric Properties of Comprehensive test Questions for Psychology major at Payame Noor University in 2006*. Master's Thesis, Faculty of Psychology and Educational Sciences, Allameh Tabatabai University. [in Persian]